第43卷 第1期
2023年2月

桂林电子科技大学学报
Journal of Guilin University of Electronic Technology

Vol. 43, No. 1
Feb. 2023

基于SOM聚类平滑图信号生成的MFR工作模式识别方法

罗 健，仇洪冰，周 陬，顾 宇，王若楠，费文浩

(桂林电子科技大学 认知无线电与信息处理教育部重点实验室，广西 桂林 541004)

摘 要：针对无人机集群截获的信号样本难以直接融合分析，以及训练样本较少且工作模式样本不平衡条件下多功能雷达(MFR)工作模式识别精度低的问题，提出了一种基于自组织映射(SOM)聚类平滑图信号生成的MFR工作模式识别方法。首先，利用分布式SOM算法对截获的信号样本集进行聚类，提取样本之间的相似性；然后，依据聚类结果将信号样本集以平滑图信号的方式表征，建立同一工作模式下信号样本的关联；最后，采用图注意力网络对上述图信号进行图节点数据融合与分类，完成MFR工作模式识别。实验结果表明，在工作模式样本不平衡度约为10∶1，每种类别训练样本数为25时，该方法的识别准确率和F1指数相对现有方法分别提高了22.8%、22.34%，且能适用于存在一定噪声干扰的情况。

关键词：MFR工作模式识别；无人机集群；平滑图信号；自组织映射；图注意力网络

中图分类号：TN974 **文献标志码**：A **文章编号**：1673-808X(2023)01-0026-08

MFR working mode recognition based on smooth graph signal generated by SOM clustering

LUO Jian, QIU Hongbing ZHOU Zou, GU Yu, WANG Ruonan, FEI Wenhao

(Key Laboratory of Cognitive Radio and Information Processing of Ministry of Education, Guilin University of Electronic Technology, Guilin 541004, China)

Abstract: UAV swarms are widely used in radar signal interception due to their advantages of wide sensing range and rapid information sharing. Aiming at the problem that the signal samples intercepted by UAV cluster are difficult to be fused and analyzed directly, and the recognition accuracy of multi-function radar (MFR) working mode is low under the condition of few training samples and unbalanced working mode samples, an MFR working mode recognition method based on smooth graph signal generated by self-organizing map (SOM) clustering is proposed. Firstly, the intercepted signal samples are clustered by using distributed SOM algorithm to extract the similarity between samples; Then, according to the clustering results, the signal sample set is characterized by smooth graph signal, and the correlation of signal samples under the same working mode is established; Finally, the graph attention network is used to fuse and classify the graph node data of the above graph signals to complete the MFR working pattern recognition. The experimental results show that, when the imbalance of working mode samples is about 10∶1 and the number of training samples in each class is 25, the recognition accuracy and F1 measure of this method are improved by 22.8% and 22.34% respectively compared with the existing methods, and can be applied to the case of noise interference.

Key words: MFR working mode recognition; UAV swarms; smooth graph signal; self-organizing map; graph attention network

雷达工作模式识别是电子侦察的核心内容，其通过对截获的信号样本进行分析处理以判定目标雷达的工作模式，为制定电子对抗策略提供情报基础[1]。多功能雷达(multi-function radar，简称MFR)因具

收稿日期：2022-05-11

基金项目：国家自然科学基金(62071135)；认知无线电与信息处理省部共建教育部重点实验室主任基金(CRKL190104)；桂林电子科技大学研究生教育创新计划(2021YCXS041)

通信作者：周陬(1983-)，男，副教授，博士，研究方向为无人机群体智能、多传感室内定位与建图、物联网与大数据技术应用。E-mail：zhouzou@guet.edu.cn

引文格式：罗健，仇洪冰，周陬，等. 基于SOM聚类平滑图信号生成的MFR工作模式识别方法[J].桂林电子科技大学学报，2023，43(1)：26-33.

有多工作模式、智能程度高、可靠性强等优点被广泛应用于电子战[2],给雷达信号侦察带来巨大挑战。MFR 信号被截获概率较低,因此在短时间内可截获的信号样本较少;若不对 MFR 施加一定对抗压力,其某些工作模式可能被隐藏[3]。将无人机集群应用于 MFR 侦察可有效应对上述问题。其不仅能通过对战场的全覆盖与信息交互得到较为完备的 MFR 信号样本集[4],还可实施模拟攻击对 MFR 施压,使其暴露所有工作模式,且应用无人机集群是电子对抗发展的大势所趋[5]。

在复杂电磁环境下,截获的信号样本通常存在脉冲丢失、测量误差较大等缺陷[6],通过数据融合能够减轻其对识别结果的影响。然而,由于各无人机截获的 MFR 信号样本通常来自多个 MFR 或不同工作模式,难以直接对其进行融合处理。因此,如何建立无人机集群截获的 MFR 信号样本之间的融合依据是必须考虑的问题。

现有的 MFR 工作模式识别方法主要包括基于隐马尔科夫模型(hidden markov model,简称 HMM)的方法、基于句法模型的方法、基于信号特征提取的方法。基于 HMM 的方法[7-9]将雷达系统视为一个有限状态自动机(finite state automaton,简称 FSA),利用 HMM 对 FSA 建模,实现 MFR 工作模式识别。该方法在保留观测信号最大信息量的同时具有很好的灵活性,但难以对状态数繁多、转换复杂的雷达系统进行准确表征。基于句法模型的方法[10-13]依据 MFR 工作模式转移的文法类型,构造相应的自动机,实现工作模式识别。该方法理论性较强,且相较于基于 HMM 的方法具有更好的雷达信号建模能力,但它十分依赖雷达的先验知识,本质上是对情报库中先验知识的符号化表征。基于信号特征提取的方法[14-16]依据不同工作模式下信号特征的差异性,构建分类器以实现 MFR 工作模式识别[17]。该方法对先验知识的需求较低,识别准确率通常较高,且对含噪数据具有较强的适应性,但训练复杂分类模型所需的大量训练样本不易获得。此外,由于 MFR 各种工作模式的运行时长不同,导致截获的信号样本集存在工作模式样本不平衡的情况,也给 MFR 工作模式识别增加了一定难度。

综上,针对无人机集群截获的信号样本难以直接融合分析以及在训练样本较少且工作模式样本不平衡时难以训练出有效分类器的问题,提出了一种基于自组织映射(self-organizing map,简称 SOM)聚类平滑图信号生成的 MFR 工作模式识别方法。利用分布式 SOM 算法对截获的信号样本进行聚类,使得同一聚类簇内的样本尽可能属于相同工作模式;根据聚类簇拓扑关系已知,且拓扑上邻近的聚类簇包含的信号样本通常具有一定相似性的特性,生成关于信号样本集的平滑图信号,图信号中存在连接的信号样本通常具有较强的相似性,以便对信号样本进行融合处理;利用图注意力网络(graph attention networks,简称 GAT)对上述平滑图信号进行一阶邻域数据融合与节点分类,实现工作模式样本不平衡且训练样本较少情况下的 MFR 工作模式识别。

1　场景描述

考虑的雷达对象为“水星”MFR,它是一部真实装备的防空雷达,Visnevski 虽未公开该雷达的信号参数、工作模式转换规律等信息,但给出了行为层面的特征。“水星”MFR 采用符号语言建模一种多层级信号结构,即雷达脉冲、雷达字、雷达短语。雷达短语由一定数量的雷达字串联而成,雷达字由一定数量的雷达脉冲串联而成[11]。此外,雷达短语之上还有雷达句子层级,但不在本研究范围内。

“水星”MFR 采用雷达短语表达工作模式,有搜索、捕获、非自适应跟踪、距离分辨、跟踪保持 5 种工作模式。由于该雷达存在少量复用的雷达短语,而本方法未考虑该问题,因此对部分雷达短语作了归并处理,处理后的“水星”MFR 工作模式及其对应的雷达短语如表 1 所示。

对抗场景如图 1 所示,其展示了 MFR 工作模式识别的一般流程。首先,利用无人侦察机截获 MFR 的信号脉冲流;然后,经过参数测量、信号分选、雷达字提取等处理提取出雷达字序列;最后,从雷达字序列中切割出一个个雷达短语,对其进行分类,以实现 MFR 工作模式识别。本研究的处理对象是雷达短语,而参数测量、信号分选、雷达字提取等算法不在本研究范畴内,但考虑了因上述算法存在误差引起的信号样本缺陷,具体而言,在仿真中考虑了存在测量误差、脉冲丢失和干扰脉冲的情况。

对无人机集群截获的雷达短语进行建模,以便开展算法研究。如表 1 所示,一个雷达短语 $\boldsymbol{B}$ 包含 4 个雷达字

$$\boldsymbol{B}=[\boldsymbol{w}_a,\boldsymbol{w}_b,\boldsymbol{w}_c,\boldsymbol{w}_d],\ a,b,c,d\in[1,9],\quad(1)$$

一个雷达字 $\boldsymbol{w}$ 具有若干个脉冲

$$\boldsymbol{w}=[\boldsymbol{p}_1,\boldsymbol{p}_2,\cdots,\boldsymbol{p}_l,\cdots,\boldsymbol{p}_L],\ 1\leqslant l\leqslant L。\quad(2)$$

由于非合作方通常只能通过分析 MFR 信号特征来推测其意图,而载频(RF)、脉宽(PW)、脉冲重复间隔(PRI)能提供许多有关 MFR 状态的关键信息[15,18-19],将脉冲表述为

表 1　"水星"MFR 工作模式及其对应的雷达短语

工作模式	雷达短语	工作模式	雷达短语
搜索	$\boldsymbol{w}_1\boldsymbol{w}_2\boldsymbol{w}_4\boldsymbol{w}_5$	跟踪保持	$\boldsymbol{w}_1\boldsymbol{w}_7\boldsymbol{w}_7\boldsymbol{w}_7$
	$\boldsymbol{w}_2\boldsymbol{w}_4\boldsymbol{w}_5\boldsymbol{w}_1$		$\boldsymbol{w}_2\boldsymbol{w}_7\boldsymbol{w}_7\boldsymbol{w}_7$
	$\boldsymbol{w}_4\boldsymbol{w}_5\boldsymbol{w}_1\boldsymbol{w}_2$		$\boldsymbol{w}_3\boldsymbol{w}_7\boldsymbol{w}_7\boldsymbol{w}_7$
	$\boldsymbol{w}_5\boldsymbol{w}_1\boldsymbol{w}_2\boldsymbol{w}_4$		$\boldsymbol{w}_4\boldsymbol{w}_7\boldsymbol{w}_7\boldsymbol{w}_7$
	$\boldsymbol{w}_1\boldsymbol{w}_3\boldsymbol{w}_5\boldsymbol{w}_1$		$\boldsymbol{w}_5\boldsymbol{w}_7\boldsymbol{w}_7\boldsymbol{w}_7$
	$\boldsymbol{w}_3\boldsymbol{w}_5\boldsymbol{w}_1\boldsymbol{w}_3$		$\boldsymbol{w}_6\boldsymbol{w}_7\boldsymbol{w}_7\boldsymbol{w}_7$
	$\boldsymbol{w}_5\boldsymbol{w}_1\boldsymbol{w}_3\boldsymbol{w}_5$		$\boldsymbol{w}_1\boldsymbol{w}_8\boldsymbol{w}_8\boldsymbol{w}_8$
捕获	$\boldsymbol{w}_1\boldsymbol{w}_1\boldsymbol{w}_1\boldsymbol{w}_1$		$\boldsymbol{w}_2\boldsymbol{w}_8\boldsymbol{w}_8\boldsymbol{w}_8$
	$\boldsymbol{w}_2\boldsymbol{w}_2\boldsymbol{w}_2\boldsymbol{w}_2$		$\boldsymbol{w}_3\boldsymbol{w}_8\boldsymbol{w}_8\boldsymbol{w}_8$
	$\boldsymbol{w}_3\boldsymbol{w}_3\boldsymbol{w}_3\boldsymbol{w}_3$		$\boldsymbol{w}_4\boldsymbol{w}_8\boldsymbol{w}_8\boldsymbol{w}_8$
	$\boldsymbol{w}_4\boldsymbol{w}_4\boldsymbol{w}_4\boldsymbol{w}_4$		$\boldsymbol{w}_5\boldsymbol{w}_8\boldsymbol{w}_8\boldsymbol{w}_8$
	$\boldsymbol{w}_5\boldsymbol{w}_5\boldsymbol{w}_5\boldsymbol{w}_5$		$\boldsymbol{w}_6\boldsymbol{w}_8\boldsymbol{w}_8\boldsymbol{w}_8$
非自适应跟踪	$\boldsymbol{w}_1\boldsymbol{w}_6\boldsymbol{w}_6\boldsymbol{w}_6$		$\boldsymbol{w}_1\boldsymbol{w}_9\boldsymbol{w}_9\boldsymbol{w}_9$
	$\boldsymbol{w}_2\boldsymbol{w}_6\boldsymbol{w}_6\boldsymbol{w}_6$		$\boldsymbol{w}_2\boldsymbol{w}_9\boldsymbol{w}_9\boldsymbol{w}_9$
	$\boldsymbol{w}_3\boldsymbol{w}_6\boldsymbol{w}_6\boldsymbol{w}_6$		$\boldsymbol{w}_3\boldsymbol{w}_9\boldsymbol{w}_9\boldsymbol{w}_9$
	$\boldsymbol{w}_6\boldsymbol{w}_6\boldsymbol{w}_6\boldsymbol{w}_1$		$\boldsymbol{w}_4\boldsymbol{w}_9\boldsymbol{w}_9\boldsymbol{w}_9$
	$\boldsymbol{w}_6\boldsymbol{w}_6\boldsymbol{w}_6\boldsymbol{w}_2$		$\boldsymbol{w}_5\boldsymbol{w}_9\boldsymbol{w}_9\boldsymbol{w}_9$
	$\boldsymbol{w}_6\boldsymbol{w}_6\boldsymbol{w}_6\boldsymbol{w}_3$		$\boldsymbol{w}_6\boldsymbol{w}_9\boldsymbol{w}_9\boldsymbol{w}_9$
距离分辨	$\boldsymbol{w}_7\boldsymbol{w}_6\boldsymbol{w}_6\boldsymbol{w}_6$		$\boldsymbol{w}_7\boldsymbol{w}_7\boldsymbol{w}_7\boldsymbol{w}_7$
	$\boldsymbol{w}_8\boldsymbol{w}_6\boldsymbol{w}_6\boldsymbol{w}_6$		$\boldsymbol{w}_8\boldsymbol{w}_8\boldsymbol{w}_8\boldsymbol{w}_8$
	$\boldsymbol{w}_9\boldsymbol{w}_6\boldsymbol{w}_6\boldsymbol{w}_6$		$\boldsymbol{w}_9\boldsymbol{w}_9\boldsymbol{w}_9\boldsymbol{w}_9$

$$\boldsymbol{p}=[p_{\mathrm{RF}},p_{\mathrm{PW}},p_{\mathrm{PRI}}],\tag{3}$$

其中，p_{RF}、p_{PW}、p_{PRI} 分别为 RF、PW、PRI。此时雷达短语可重写为

$$\boldsymbol{B}=[\boldsymbol{p}_{\mathrm{RF}}^{k},\boldsymbol{p}_{\mathrm{PW}}^{k},\boldsymbol{p}_{\mathrm{PRI}}^{k}],\quad k=1,2,3,4,\tag{4}$$

其中，$\boldsymbol{p}_{\mathrm{RF}}^{k}$ 为第 k 个雷达字中所有脉冲的 RF 序列。由于引入无人机集群截获 MFR 信号，截获的全部信号样本可表示为

$$X=\{\boldsymbol{B}_n^m \mid n=1,2,\cdots,N_{\mathrm{u}},\ m=1,2,\cdots,M_n\},\tag{5}$$

其中，$\boldsymbol{B}_n^m$ 为无人机 n 接收的第 m 个雷达短语。

最后，设计一种 MFR 工作模式识别方法 $f(\cdot)$，即

$$\hat{Y}=f(X),\tag{6}$$

其中，$\hat{Y}=\{\hat{y}_n^m \mid n=1,2,\cdots,N_{\mathrm{u}},\ m=1,2,\cdots,M_n\}$，$\hat{y}_n^m$ 为无人机 n 接收的第 m 个雷达短语的分类结果。

2　基于 SOM 聚类平滑图信号生成的 MFR 工作模式识别方法

系统框图如图 2 所示。首先，利用无人机集群截获 MFR 的信号样本，并采用分布式 SOM 算法对其进行聚类，使得同一聚类簇内的信号样本尽可能属于同一类别，且相邻簇包含的信号样本也具有一定相似性，而距离较远的簇包含的信号样本差异通常较大。

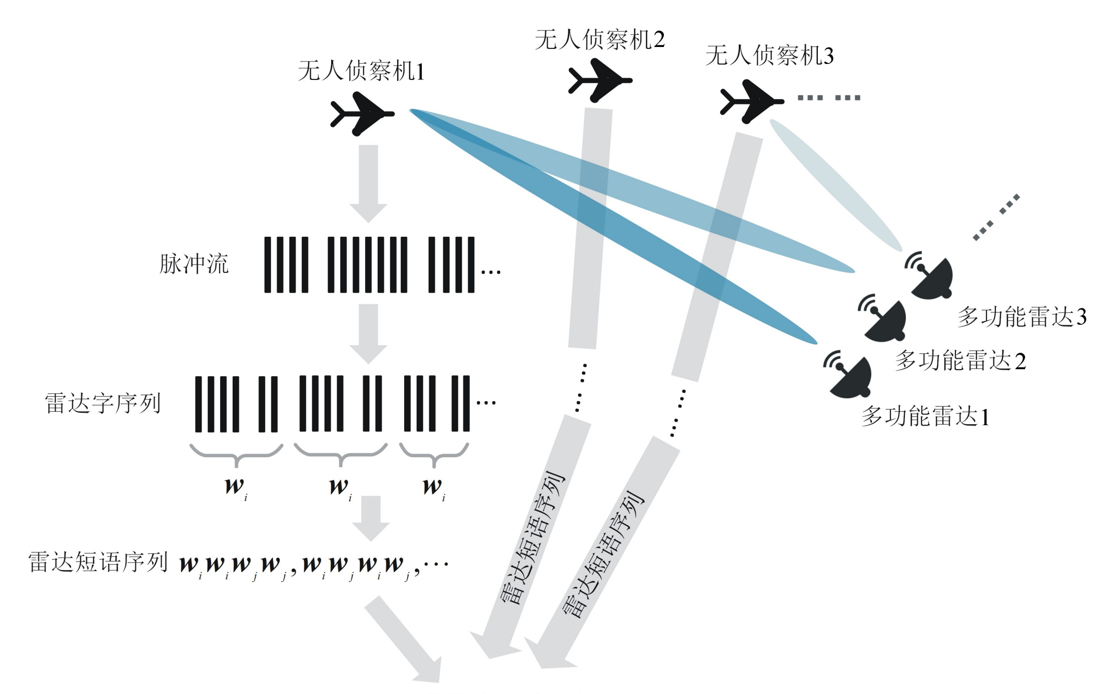


图 1　无人机集群与多 MFR 对抗场景

其次,依据上述聚类结果的特性生成关于信号样本集的平滑图信号,即对于任一聚类簇内的样本而言,在图信号上表现为簇内样本全连接、与相邻簇内的部分样本连接,使得图中任一节点的一阶邻域内通常没有与之差异较大的节点,以便进行节点融合处理。最后,将图结构以及各图节点对应的信号样本特征作为 GAT 的输入,进行节点数据融合与分类,实现 MFR 工作模式识别。在数据融合阶段仅考虑一阶邻域,以尽可能地避免节点受到非同类节点的影响,从而提取出各工作模式的差异性,应对工作模式样本不平衡;在进行数据融合的同时完成类别信息传递,应对训练样本较少情况。

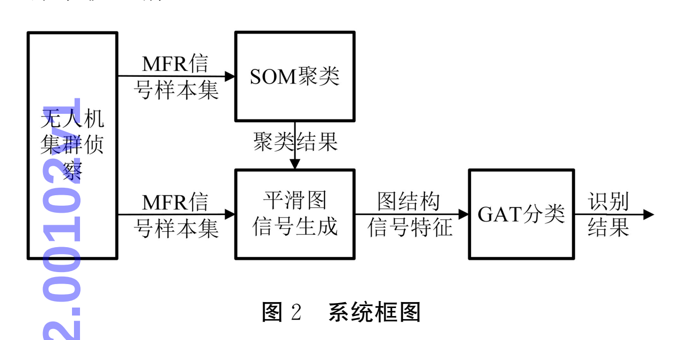


图 2　系统框图

2.1　基于 SOM 的平滑图信号生成算法

与一般聚类算法不同,SOM 算法依据一定拓扑结构初始化聚类簇中心,图 3 为聚类簇拓扑结构,图中椭圆表示聚类簇。在迭代过程中,先计算输入信号样本与各聚类簇中心的距离,与之距离最小的簇为优胜簇;然后将优胜簇及其邻居簇的中心朝该信号样本方向调整,而拓扑结构上与优胜簇距离较远的簇基本不受影响,进而保持簇拓扑结构不变,且相邻簇包含的信号样本具有较强的相似性[20]。

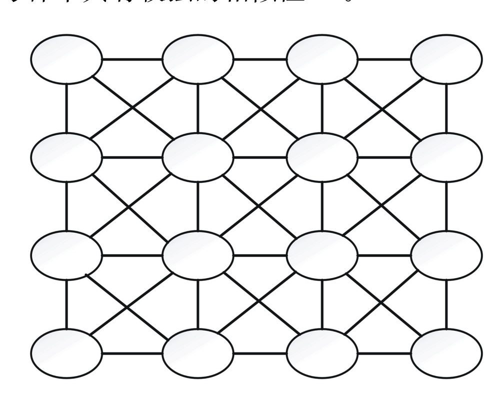


图 3　聚类簇的矩形网格拓扑结构

采用的 SOM 算法适用于无人机集群分布式处理架构,如算法 1 所示。$N_{u,v}^{i,j}$ 为以第 u 行第 v 列的簇为中心的邻域函数,

$$N_{u,v}^{i,j}=\exp\left(-\frac{d_{u,v}^{i,j}}{2\sigma^2}\right),\tag{7}$$

其中:σ 为邻域因子;$d_{u,v}^{i,j}$ 为第 u 行第 v 列的簇与第 i 行第 j 列的簇的欧氏距离。

算法 1　分布式 SOM 算法

输入:$X=\{\boldsymbol{B}_n^m \mid n=1,2,\cdots,N_{\mathrm{u}},\ m=1,2,\cdots,M_n\}$,矩形网格的行数 r 和列数 c,初始学习率 η_0,初始邻域因子 σ_0,最大迭代次数 E。

输出:各聚类簇中心 $Q(t)=\{\boldsymbol{q}_{i,j}(t) \mid i=1,2,\cdots,r,\ j=1,2,\cdots,c\}$;聚类结果 $S=\{\boldsymbol{s}_n^m \mid n=1,2,\cdots,N_{\mathrm{u}},\ m=1,2,\cdots,M_n\}$。

```
随机初始化 Q(0)
t ← 0
η(t) ← η_0
σ(t) ← σ_0
for iter ← 1 to E do
    for n ← 1 to N_u do
        for m ← 1 to M_n do
            [u,v] ← argmin_{i,j}(B_n^m − q_{i,j}(t))
            对所有簇执行 q_{i,j}(t+1) ← q_{i,j}(t) +
            η(t) N_{u,v}^{i,j}(t) [B_n^m − q_{i,j}(t)]
            η(t+1) ← η_0/t
            σ(t+1) ← σ_0/t
            t ← t+1
        end for
    end for
end for
for n ← 1 to N_u do
    for m ← 1 to M_n do
        [u,v] ← argmin_{i,j}(B_n^m − q_{i,j}(t))
        s_n^m ← [u,v]
    end for
end for
```

对于 SOM 聚类结果而言,拓扑上相邻的聚类簇在数据空间中也相邻,即拓扑上相邻的簇所包含的样本通常较为相似,因此依据簇邻居关系能够生成关于信号样本集的平滑图信号。根据簇内样本全连接、相邻簇的部分样本连接、不相邻的簇不作处理的原则,给出一种基于 SOM 的平滑图信号生成算法。算法如下:

1) 初始化邻接矩阵 $\boldsymbol{A}=\boldsymbol{I}_{N_X}$,$\boldsymbol{I}_{N_X}$ 为维度为 N_X 的单位矩阵,N_X 为样本总数,初始化邻居簇的连接比例为 r_{c};

2) 选择一个簇为主簇,令主簇所含样本集的索

引为 $\boldsymbol{d}_{\mathrm{m}} \in \mathbf{R}^{N_{\mathrm{m}}}$，其中 N_{m} 为主簇内样本数。将这些样本作全连接处理，即邻接矩阵中对应项置 1，$\boldsymbol{A}(\boldsymbol{d}_{\mathrm{m}},\boldsymbol{d}_{\mathrm{m}})=1$；

3) 分别计算各邻居簇所含样本与主簇中心的距离，取其中距离最小的若干个样本的索引 $\boldsymbol{d}_{\mathrm{v}}=[\boldsymbol{d}_{\mathrm{v}}^{1},\boldsymbol{d}_{\mathrm{v}}^{2},\cdots,\boldsymbol{d}_{\mathrm{v}}^{N_{\mathrm{n}}}]$，其中 $\boldsymbol{d}_{\mathrm{v}}^{i} \in \mathbf{R}^{\lfloor n_i \times r_{\mathrm{c}} \rfloor}$，$N_{\mathrm{n}}$ 为邻居簇数，n_i 为第 i 个邻居簇所含样本数；

4) 从 $\boldsymbol{d}_{\mathrm{v}}$ 中选取一个值，令其为 i_{v}，在主簇中随机取 $N_{\mathrm{m}} \times r_{\mathrm{c}}$ 个样本的索引 $\boldsymbol{d}'_{\mathrm{m}}$，执行 $\boldsymbol{A}(i_{\mathrm{v}},\boldsymbol{d}'_{\mathrm{m}})=1$，重复该步骤，直至 $\boldsymbol{d}_{\mathrm{v}}$ 中所有项都执行过步骤 4)；

5) 返回步骤 2)，直至所有簇都曾被设为主簇。

2.2 图注意力网络

GAT 由若干个图注意力层堆叠构造[21]。任一层的输入为邻接矩阵和图信号中所有节点的特征向量 $\boldsymbol{h}=[\boldsymbol{h}_1,\boldsymbol{h}_2,\cdots,\boldsymbol{h}_N]$，$\boldsymbol{h}_i \in \mathbf{R}^F$，其中 N 为节点总数，F 为节点特征维度，输入层的图节点特征向量如式(4)所示。为实现特征提取，引入一个可学习的线性变换矩阵 $\boldsymbol{W} \in \mathbf{R}^{F' \times F}$，此时节点 j 对节点 i 的注意力系数(即权重)为

$$e_{ij}=\mathrm{Attention}(\boldsymbol{W}\boldsymbol{h}_i,\boldsymbol{W}\boldsymbol{h}_j), \tag{8}$$

其中，Attention(•) 为单层前馈网络，Attention:$\mathbf{R}^{F'} \times \mathbf{R}^{F'} \rightarrow \mathbf{R}$。只考虑节点一阶邻居对节点的影响，并对 e_{ij} 作 softmax 归一化，得

$$\alpha_{ij}=\mathrm{softmax}_j(e_{ij})=\frac{\exp(e_{ij})}{\sum\limits_{k \in N^i}\exp(e_{ik})}, \tag{9}$$

其中：α_{ij} 为节点 j 对节点 i 的注意力系数；N^i 为节点 i 的一阶邻居节点集。采用 LeakyReLU 函数增强非线性，并将 Attention($\boldsymbol{W}\boldsymbol{h}_i,\boldsymbol{W}\boldsymbol{h}_j$) 展开，得

$$\alpha_{ij}=\frac{\exp(\mathrm{LeakyReLU}(\boldsymbol{a}^{\mathrm{T}}[\boldsymbol{W}\boldsymbol{h}_i \parallel \boldsymbol{W}\boldsymbol{h}_j]))}{\sum\limits_{k \in N^i}\exp(\mathrm{LeakyReLU}(\boldsymbol{a}^{\mathrm{T}}[\boldsymbol{W}\boldsymbol{h}_i \parallel \boldsymbol{W}\boldsymbol{h}_k]))}, \tag{10}$$

其中 $\boldsymbol{a} \in \mathbf{R}^{2F'}$ 为 Attention(•) 的权值向量。此时单层输出为

$$\boldsymbol{h}'_i=\sigma\Big(\sum_{j \in N^i}\alpha_{ij}\boldsymbol{W}\boldsymbol{h}_j\Big), \tag{11}$$

其中，$\sigma(\cdot)$ 为激活函数，$\boldsymbol{h}'_i \in \mathbf{R}^{F'}$。引入多头注意力机制后，即多个权重，单层的输出为

$$\boldsymbol{h}'_i=\mathop{\Big\Vert}_{k=1}^{K}\sigma\Big(\sum_{j \in N^i}\alpha_{ij}^{k}\boldsymbol{W}^{k}\boldsymbol{h}_j\Big), \tag{12}$$

其中，K 为注意力数，$\boldsymbol{h}'_i \in \mathbf{R}^{KF'}$。GAT 输出层通过对多头注意力取平均值，得到最终结果[21]，即信号样本所属的工作模式：

$$\boldsymbol{z}_i=\sigma\Big(\frac{1}{K}\sum_{k=1}^{K}\sum_{j \in N^i}\alpha_{ij}^{k}\boldsymbol{W}^{k}\boldsymbol{h}_j\Big)。 \tag{13}$$

3 仿真实验与分析

3.1 实验设置

仿真场景设 MFR 数 $N_{\mathrm{r}}=3$、无人机数 $N_{\mathrm{u}}=100$，为体现一般性，将无人机随机分布于 MFR 的扫描空域，无人机处于任一 MFR 波束内即认为该信号接收成功。每次仿真截获信号样本数约为 3 500 个，不平衡度(样本数最多与最少的类别的平均样本数比例)约为 10∶1，假设各 MFR 雷达字参数如表 2 所示。为降低实验结果的偶然性偏差，规定在每次仿真中各 MFR 均从最大参数范围内随机选定特征参数的子区间，特征参数为 RF、PW 和 PRI，并将该子区间作为该次仿真参数范围。若无特别说明，随机变量均服从均匀分布。根据文献[22]设定表 2 中的几种脉间调制方式，其中固定调制方式表示在一个雷达字内，脉冲特征参数值固定不变，该值从一定范围内随机选取；滑变调制方式下，雷达字中各脉冲的特征参数根据脉冲数目等间隔地从最小值取到最大值；捷变调制方式下，脉冲特征参数在一定范围内随机取值；抖动调制方式下，脉冲特征参数围绕某一中心值在±5%范围内随机抖动。另外，为使各雷达字时长基本相同，令雷达字 $\boldsymbol{w}_1 \sim \boldsymbol{w}_3$ 均包含 30 个脉冲，$\boldsymbol{w}_4 \sim \boldsymbol{w}_6$ 均包含 40 个脉冲，$\boldsymbol{w}_7 \sim \boldsymbol{w}_9$ 均包含 50 个脉冲。

表 2 MFR 雷达字参数设置

参数		$\boldsymbol{w}_1 \sim \boldsymbol{w}_3$	$\boldsymbol{w}_4 \sim \boldsymbol{w}_6$	$\boldsymbol{w}_7 \sim \boldsymbol{w}_9$
RF	最大参数范围/GHz	[3, 4]	[4, 5]	[5, 6]
	子区间长度/MHz	200	200	200
	脉间调制方式	固定	滑变	捷变
PW	最大参数范围/μs	[1, 2]	[2, 3]	[3, 4]
	子区间长度/μs	0.3	—	0.3
	脉间调制方式	固定	抖动	滑变
PRI	最大参数范围/μs	[150, 200]	[100, 150]	[50, 100]
	子区间长度/μs	10	10	—
	脉间调制方式	固定	滑变	抖动

为模拟实际环境，仿真考虑了 3 类样本缺陷，如表 3 所示。由于 PRI 是相邻两脉冲到达时间(Time of Arrival，简称 TOA)的差分值，通过对 TOA 添加测量噪声以影响 PRI。测量噪声服从均值为 0，标准差如表 3 所示的高斯分布。

表 3　不同场景参数设置

场景	RF、PW、TOA 测量噪声标准差/(MHz，μs，μs)	脉冲丢失率/%	干扰脉冲率/%
1	[0，0，0]	0	0
2	[2，0.05，2]	5	5
3	[4，0.1，4]	10	10
4	[6，0.15，6]	15	15

SOM 算法的单行、列聚类簇个数均为 30，初始学习率 η_0 和初始领域因子 σ_0 分别为 0.7 和 1.5，邻居簇的连接比例 r_c 为 0.01，邻居簇的数目为 4，即上、下、左、右方向上的邻居簇。本文采用的 GAT 包含 2 个图注意力层，第一层的注意力头数为 8，每头注意力提取的特征数为 20，然后利用 ELU(exponential linear unit)激活函数增强非线性；第二层用于分类，注意力头数为 1，激活函数采用 softmax，注意力提取的特征数为 15，分别对应 15 个类别，学习方式为直推式学习，迭代轮次为 1 000，优化器为 Adam，图注意力层的 dropout 比例为 0.2。本算法在计算距离时采用欧氏距离。为消除量纲影响，对数据进行标准化处理：

$$x = \frac{x - \text{mean}(x)}{\text{std}(x)}, \tag{14}$$

其中，mean(•)、std(•) 分别为均值、标准差。硬件配置为：Intel® Core™ i9-10900X CPU @2.20 GHz 中央处理器；NVIDIA GeForce RTX 3070 图像处理器；16 GiB 内存。

3.2　方法性能对比分析

为验证本文方法的性能，对比了基于分层序列到序列长短期记忆网络的 MFR 工作模式识别方法(记为 HSSLSTM)，除特别说明外，该算法的仿真参数与文献[15]一致。为讨论在训练样本较少时的识别效果，仿真了每种类别训练样本数 $n_s = 1,2,3,4,5,10,15,20,25$ 的情况；为讨论样本缺陷对识别结果的影响，分别对表 3 中 4 种场景进行实验。采用准确率、F1 指数(常用于类别不平衡场景)作为评价指标，上述每种情况都进行 100 次仿真实验并取其结果平均值，如图 4 所示。

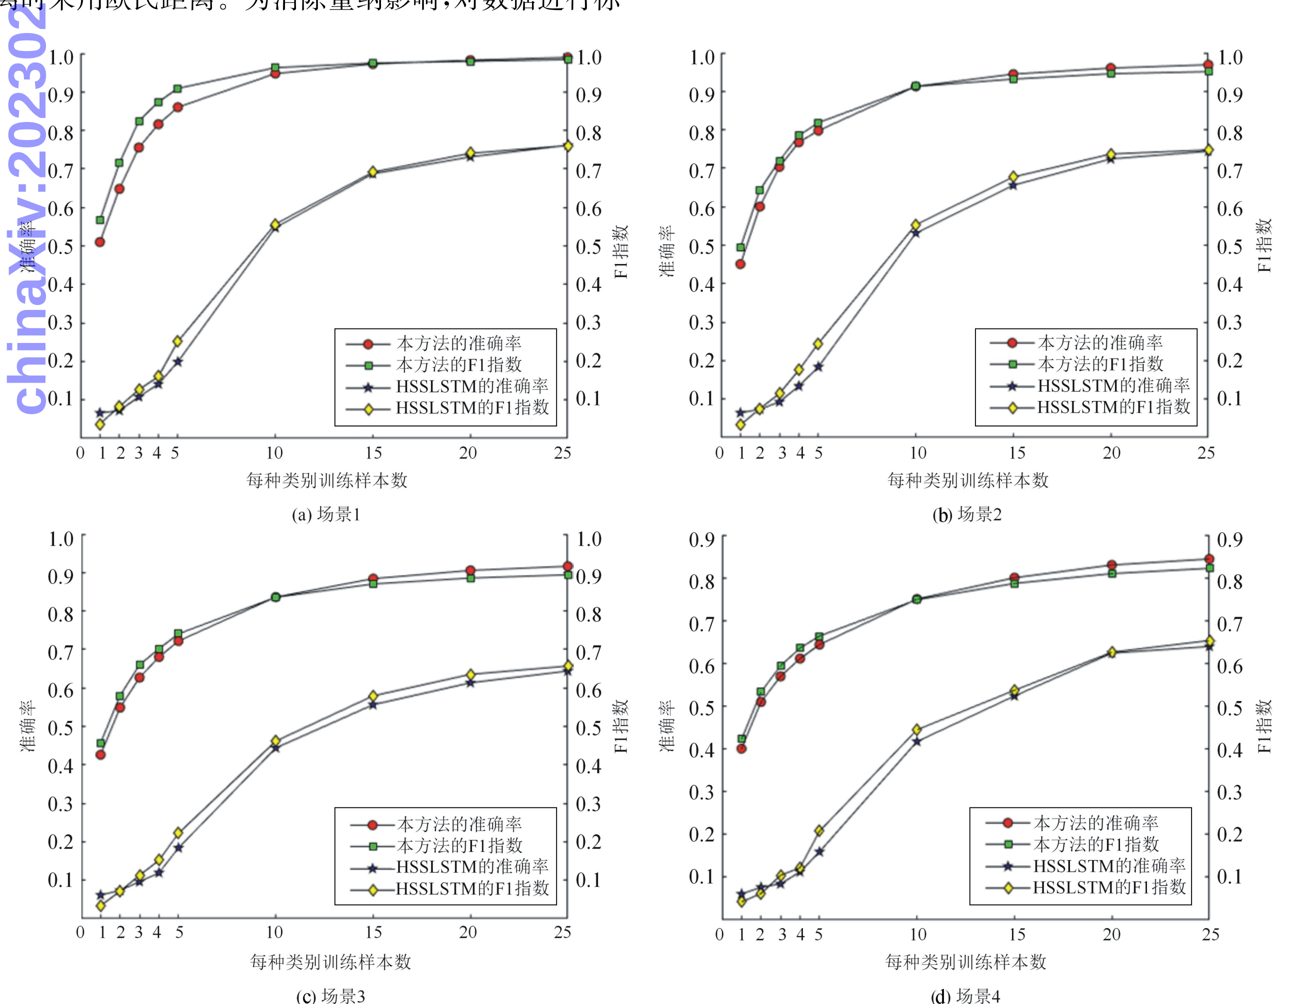


图 4　2 种方法在 4 种场景下的识别结果

由图 4 可知，随着训练样本数的增多，各场景下 2 种方法的准确率和 F1 指数均呈增长趋势。由于 HSSLSTM 采用的神经网络模型相对较为复杂，需要优化的参数较多，因此在训练样本较少时泛化性能较差，尤其在 $n_s \leqslant 5$ 时，基本无法训练出有效分类器。而本文方法通过生成关于信号样本集的平滑图信号，将相同工作模式下的信号样本进行连接；然后依据样本之间的关联，采用 GAT 模型进行节点信息融合与分类。其中，将融合范围限制在一阶邻域，从而减少不同工作模式样本间的干扰，以应对工作模式样本不平衡；利用 GAT 进行邻域类别信息传递，以摆脱对大规模训练样本的依赖。

对于场景 1，即图 4(a)所示。当 $n_s=25$ 时，即训练样本数占比约为 10.71%，本方法的准确率和 F1 指数分别为 98.95%、98.39%，而 HSSLSTM 识别准确率和 F1 指数分别为 76.15%、76.05%，相比分别提升了 22.8%、22.34%。但本方法运行时间相对于 HSSLSTM 更长，当 $n_s=25$ 时，本方法中生成平滑图信号的平均用时为 2.11 s，训练 GAT 的平均用时为 26.13 s，而 HSSLSTM 的平均用时为 7.52 s。HSSLSTM 用时较少的主要原因是训练样本数少，而 GAT 需要进行节点融合操作，故用时相对较多。

通过对比 4 种场景下 2 种方法的识别准确率和 F1 指数可发现，随着场景中噪声干扰愈发严重，2 种方法的识别准确率和 F1 指数基本呈下降趋势。这是由于截获的信号样本受噪声干扰导致存在一定程度的样本缺陷，利用这些存在缺陷的样本训练算法模型会降低模型的泛化性能。但即使在场景 4 中，即图 4(d)所示，本方法在 $n_s=25$ 时的识别准确率和 F1 指数分别为 84.38%、82.19%，说明本方法能够克服一定程度的样本缺陷。

3.3 聚类数对识别结果的影响分析

为了探究分布式 SOM 算法的聚类数对 MFR 工作模式识别效果的影响，仿真了 6 种单行、列聚类数取值下本方法的识别准确率，每种类别训练样本数为 25。此外，还考虑了表 3 所示的 4 种场景，对每种情况进行 100 次仿真实验并取结果平均值，仿真结果如表 4 所示。

从表 4 可看出，识别准确率随聚类数增多而提高，但在不同噪声干扰条件下影响不同，在噪声干扰较小时，如场景 1 和场景 2，单行、列聚类簇数在大于 15 时的增长率开始趋于平缓；而在噪声干扰较大时，如场景 3 和场景 4，这一增长率依然较高。具体而言，在场景 1 下，单行、列聚类簇数为 15 和 30 时的识别准确率仅相差 1.22%；而在场景 4 下，单行、列聚类簇数为 15 和 30 时的识别准确率相差 10.31%。这是由于场景 1 中未考虑噪声干扰，因此依靠少量聚类簇即可生成较好的平滑图信号，且 GAT 的分类性能也未受到噪声影响；而在场景 4 下，由于噪声干扰引起的样本缺陷较为严重，使得生成平滑图信号和 GAT 训练过程都受到较大影响，导致识别精度显著下降。

表 4　不同簇数下的 MFR 工作模式识别准确率

单行、列簇数	场景 1	场景 2	场景 3	场景 4
5	0.888 1	0.814 6	0.701 1	0.603 2
10	0.950 3	0.891 3	0.774 5	0.695 8
15	0.977 3	0.919 8	0.821 4	0.740 7
20	0.986 6	0.944 3	0.872 5	0.812 7
25	0.987 6	0.957 2	0.898 3	0.829 7
30	0.989 5	0.968 9	0.916 3	0.843 8

4　结束语

从建立无人机集群截获的 MFR 信号样本的融合依据出发，针对现有方法在训练样本较少且工作模式样本不平衡情况下识别精度低的问题，提出了一种基于 SOM 聚类平滑图信号生成的 MFR 工作模式识别方法。利用分布式 SOM 算法对无人机集群截获的信号样本集进行聚类，依据聚类结果以平滑图信号的方式表征信号样本集，采用 GAT 完成图节点分类，实现 MFR 工作模式识别。实验结果证明了本方法的可行性及对于样本缺陷问题的适用性。但本方法在应用分类器阶段未考虑分布式架构，针对该问题还需进一步研究。

参考文献：

[1] 欧健. 多功能雷达行为辨识与预测技术研究[D]. 长沙：国防科技大学，2017：1-2.

[2] VISNEVSKI N A. Syntactic modeling of multi-function radars[D]. Hamilton：McMaster University，2005：3-4.

[3] 王沙飞，鲍雁飞，李岩. 认知电子战体系结构与技术[J]. 中国科学：信息科学，2018，48(12)：19-29.

[4] 孙佳琛，王金龙，陈瑾，等. 群体智能协同通信：愿景、模型和关键技术[J]. 中国科学：信息科学，2020，50(3)：307-317.

[5] 张邦楚，廖剑，匡宇等. 美国无人机集群作战的研究现状与发展趋势[J]. 航空兵器，2020，27(6)：7-12.

[6] 周兰兰，仇洪冰，周陬，等. 基于数据场聚类与时差的雷达信号分选方法[J]. 桂林电子科技大学学报，2021，41(2)：92-98.

[7] LAVOIE P. Hidden Markov modeling for radar elec-

tronic warfare[P]. America:6788243,2004-9-7.

[8] VISNEVSKI N, HAYKIN S, KRISHNAMURTHY V, et al. Hidden markov models for radar pulse train analysis in electronic warfare[C]//ICASSP 2005. Piscataway, NJ: IEEE, 2005:597-600.

[9] ARASARATNAM I, HAYKIN S, THIAGALINGAM K, et al. Tracking the mode of operation of multi-function radars[C]//Proceedings of the IEEE Conference on Radar. Piscataway, NJ: IEEE, 2006:233-238.

[10] VISNEVSKI N, KRISHNAMURTHY V, HAYKIN S, et al. Multi-function radar emitter modelling: a stochastic discrete event system approach[C]//Proceedings of the 42nd IEEE International Conference on Decision and Control. Piscataway, NJ: IEEE, 2003: 6295-6300.

[11] VISNEVSKI N, KRISHNAMURTHY V, WANG A, et al. Syntactic modeling and signal of multifunction radars: a stochastic context-free grammer approach[J]. Proceedings of the IEEE, 2007, 95(5):1000-1025.

[12] WANG A, KRISHNAMURTHY V. Signal interpretation of multifunction radars: modeling and statistical signal processing with stochastic context free grammar [J]. IEEE Transactions on Signal Processing, 2008, 56 (3):1106-1119.

[13] 刘海军,李悦,柳征,等. 基于随机文法的多功能雷达识别方法[J]. 航空学报,2010,31(9):1809-1817.

[14] LIU Z M, YU P S. Classification, denoising, and deinterleaving of pulse streams with recurrent neural networks[J]. IEEE Transactions on Aerospace Electronic Systems, 2019, 55(4):1624-1639.

[15] LI Y, ZHU M, MA Y, et al. Work modes recognition and boundary identification of MFR pulse sequences with a hierarchical seq2seq LSTM[J]. IET Radar Sonar and Navigation, 2020, 14(9):1343-1353.

[16] LIU Z M. Recognition of multifunction radars via hierarchically mining and exploiting pulse group patterns [J]. IEEE Transactions on Aerospace and Electronic Systems, 2020, 56(6):4659-4672.

[17] 阳榴,朱卫纲,吕守业,等. 多功能雷达工作模式识别方法综述[J]. 电讯技术,2020,60(11):1384-1390.

[18] KAUPPI J P, MARTIKAINEN K, RUOTSALAINEN U. Hierarchical classification of dynamically varying radar pulse repetition interval modulation patterns[J]. Neural Networks, 2010, 23(10):1226-1237.

[19] 刘章孟,袁硕,康仕乾. 多功能雷达脉冲列的语义编码与模型重建[J]. 雷达学报,2021,10(4):559-570.

[20] KOHONEN T. Essentials of the self-organizing map [J]. Neural Networks, 2013, 37(1):52-65.

[21] VELIKOVI P, CUCURULL G, CASANOVA A, et al. Graph attention networks[C]//Proceedings of the International Conference on Learning Representations 2018. openreview. net, 2018:1-12.

[22] WILEY R G. ELINT: the interception and analysis of radar signals[M]. Boston, MA: Artech House, 2006: 281-287.

编辑:张所滨